

UNIVERSIDAD AUTÓNOMA DE MADRID  
ESCUELA POLITÉCNICA SUPERIOR



Grado en Ingeniería de Tecnologías y Servicios de Telecomunicación

TRABAJO FIN DE GRADO

Detección del nivel de llenado de un  
recipiente translúcido de estructura  
conocida

Raquel García Iglesias  
Tutor: Jesús Bescós Cano

Junio 2019



# **Detección del nivel de llenado de un recipiente translúcido de estructura conocida**

**Raquel García Iglesias**  
**Tutor: Jesús Bescós Cano**



**Video Processing and Understanding Lab**  
**Departamento de Tecnología Electrónica y de las Comunicaciones**  
**Escuela Politécnica Superior**  
**Universidad Autónoma de Madrid**  
**Junio 2019**



# Resumen

Este Trabajo de Fin de Grado tiene como objetivo principal poder detectar a través de una máscara, el nivel de llenado que contiene un recipiente. Dicho recipiente se caracteriza por ser translúcido y por tener una determinada estructura conocida. Para conseguir los resultados deseados respecto al nivel de llenado será necesario abordar diversos puntos.

La máscara a través de la cual se debe iniciar este estudio no se proporciona para la elaboración de este trabajo, por lo que habrá que hacer una simulación de la misma. Se estudiarán las vías correspondientes para poder llegar a este propósito. Para poder encontrar el nivel de llenado del recipiente se analizarán sus propiedades y se evaluarán diferentes técnicas para poder encontrar la región correspondiente al líquido dentro del objeto. Se trabajará con entornos de color, tamaños de píxeles y distancias entre los mismos. Además, una vez localizada el área del líquido se tendrá que desarrollar un método para poder analizar el volumen real que contiene.

Todas las etapas por las que pasará este estudio se han realizado mediante una investigación basada en métodos y algoritmos de detección y segmentación, que se irán desarrollando a lo largo de la evolución del proyecto.

Para llevar a cabo todos estos procesos y poder evaluar finalmente los resultados ofrecidos, se ha recopilado una colección de imágenes con varios niveles de llenado. De esta manera se podrá estudiar el efecto que tendrán los algoritmos implementados sobre las imágenes recogidas, determinando así la eficacia de los mismos.

# Palabras clave

Segmentación, detección, nivel de llenado, orientación, superpíxeles, clustering, máscara, entorno de color...



# Abstract

The aim of this work is obtaining through an image's mask, the liquid's level which is inside of a container. This container is characterized by having a known structure and being translucent. To obtain the desired results, it is necessary to deal with various issues.

The mask through which this study should be started, is not given to prepare this project. For that reason it will be necessary to create a mask simulation. Techniques to reach this goal will be explored in the next chapters.

To find the container's fill level, its properties will be analysed and different techniques will be evaluated to be able to locate the region which belongs to the liquid inside the container. For the duration of the project we will be working with color models, pixels sizes and distances between them. Besides that, once the liquid's area has been located, it will be requested to develop a method to analyze the actual volumen which is in inside it.

All the project's stages have been achieved by means of an investigation based on detection and segmentation algorithms which will be developed throughout the evolution of the research. To carry out these processes and finally evaluate the results, a collection of images with different fill levels has been gathered making it possible to study the effect that the implemented algorithms will have on the images collected, thus determining their efficiency.

# Keywords

Segmentation, detection, fill level, orientation, superpixels, clustering, mask, color model. . .





# Agradecimientos

*En primer lugar agradecer a mi tutor, Jesús Bescós, la ayuda que me ha ofrecido guiándome en la realización de este trabajo.*

*Además, quisiera dar las gracias principalmente a mi madre, por darme la oportunidad de tener una buena educación, y especialmente por creer y confiar en mí durante todos estos años. Agradecer también a todas aquellas personas que me he encontrado en el camino y que me han apoyado y ayudado a continuar y poder ser capaz de cerrar esta etapa.*

*Finalmente, gracias a vosotros, que, aunque ya no estéis aquí se que me estáis dando fuerzas y guiando desde algún lugar.*



# Índice general

|  |            |
|--|------------|
| <b>Resumen</b>   | <b>v</b>   |
| <b>Abstract</b>  | <b>vii</b> |
| <b>Agradecimientos</b>   | <b>ix</b>  |
| <b>1. Introducción</b>   | <b>1</b>   |
| 1.1. Motivación . . . . .  | 1          |
| 1.2. Objetivos . . . . .   | 2          |
| 1.3. Organización de la memoria . . . . .                                      | 2          |
| <b>2. Estado del arte</b>  | <b>3</b>   |
| 2.1. Introducción . . . . .  | 3          |
| 2.2. Áreas de estudio . . . . .  | 3          |
| 2.2.1. Detección por aproximación . . . . .                                    | 3          |
| 2.2.2. Segmentación . . . . .  | 5          |
| 2.2.3. Clustering . . . . .  | 8          |
| 2.3. Herramientas . . . . .  | 8          |
| 2.3.1. Matlab . . . . .  | 8          |
| 2.4. Conclusiones . . . . .  | 8          |
| <b>3. Diseño y desarrollo</b>  | <b>9</b>   |
| 3.1. Introducción . . . . .  | 9          |
| 3.2. Visión general . . . . .  | 9          |
| 3.3. Algoritmos de detección por aproximación . . . . .                        | 9          |
| 3.3.1. Contornos Activos . . . . .   | 9          |
| 3.3.2. Detección zonas de color . . . . .                                      | 10         |
| 3.4. Algoritmos de segmentación y clustering . . . . .                         | 11         |
| 3.4.1. Simple Linear Iterative Clustering . . . . .                            | 11         |
| 3.4.2. SuperPixel Density Based Spactial Clustering of Applications with Noise | 12         |
| 3.4.3. Fuzzy C-Means . . . . .   | 13         |
| 3.5. Nivel de llenado . . . . .  | 14         |
| <b>4. Evaluación</b>   | <b>19</b>  |
| 4.1. Introducción . . . . .  | 19         |
| 4.2. Marco de evaluación . . . . .   | 19         |
| 4.3. Pruebas y resultados . . . . .  | 19         |
| 4.4. Conclusión . . . . .  | 25         |

|   |           |
|---|-----------|
| <b>5. Conclusiones y trabajo futuro</b> | <b>27</b> |
| 5.1. Conclusiones . . . . .             | 27        |
| 5.2. Trabajo futuro . . . . .           | 28        |
| <b>Bibliografía</b>                     | <b>29</b> |

# Índice de figuras

|  |    |
|--|----|
| 1.1. Recipiente de estructura conocida . . . . .             | 1  |
| 2.1. Imagen algoritmo de Canny . . . . .                     | 4  |
| 2.2. Imagen algoritmo de Contornos Activos . . . . .         | 4  |
| 2.3. Cono representativo del sistema de color HSV . . . . .  | 5  |
| 2.4. Método de búsqueda K-Means . . . . .                    | 6  |
| 3.1. Diagrama de bloques . . . . .                           | 10 |
| 3.2. Máscaras Contornos Activos . . . . .                    | 10 |
| 3.3. Canales HSV . . . . .                                   | 11 |
| 3.4. Segmentación del recipiente . . . . .                   | 13 |
| 3.5. Histogramas de los Niveles de Grises . . . . .          | 14 |
| 3.6. Ejemplo de imagen desviada . . . . .                    | 15 |
| 3.7. Ejes de orientación . . . . .                           | 16 |
| 4.1. Dataset . . . . .                                       | 20 |
| 4.2. Máscara resultante de contornos activos . . . . .       | 20 |
| 4.3. Máscara resultante por detección de color HSV . . . . . | 21 |
| 4.4. Máscara Final . . . . .                                 | 21 |
| 4.5. Resultado algoritmo Fuzzy C-Means . . . . .             | 22 |
| 4.6. Eje de orientación final en Fuzzy . . . . .             | 22 |
| 4.7. Gráfica niveles de llenado . . . . .                    | 23 |
| 4.8. Imagen con ángulo inclinado . . . . .                   | 24 |
| 4.9. Gráfica casos de estudio fallidos . . . . .             | 24 |



# Índice de tablas

|  |    |
|--|----|
| 4.1. Datos recogidos de los niveles de llenado . . . . . | 23 |
|--|----|





# Capítulo 1

## Introducción

### 1.1. Motivación

La motivación principal de este proyecto es ser capaz de llegar a detectar de manera eficiente el nivel de líquido que corresponde al volumen de un recipiente. Este recipiente es de estructura conocida y queda recogido en la figura 1.1. Para conseguir esta meta se proporciona de entrada una máscara del objeto, resultado de otro trabajo previo cuya finalidad era detectar y localizar el objeto dentro de una imagen mediante una aplicación de móvil.

El propósito que mueve a este trabajo, por tanto, es conseguir encontrar a partir de dicha máscara y del estudio de múltiples algoritmos, el resultado que mejor se adapte al cálculo del nivel de llenado real del recipiente. Además, el caso de estudio que se va a exponer durante este proyecto se podría adaptar para ser utilizado en campos de medicina, química u otras áreas científicas o de investigación donde detectar el nivel de llenado de un objeto sea necesario. Por lo que la motivación que mueve a este Trabajo de Fin de Grado no sólo es conseguir la detección del nivel de llenado del recipiente, si no, además, hacerlo con los resultados más eficientes y óptimos posibles.



Figure 1.1: Recipiente vacío en el que se realizarán las pruebas de nivel de llenado

## 1.2. Objetivos

El objetivo principal en el que se enfoca este proyecto es el de detectar a través de una fotografía, el nivel de llenado de un determinado recipiente de forma conocida. Para ello, es necesario abordar los siguientes propósitos:

-Inicialmente es fundamental contar con una base de imágenes lo suficientemente grande y que cuente con distintos niveles de llenados a las que poder aplicar los desarrollos que se explicarán más adelante.

-Aunque el proyecto comienza a partir de la máscara del recipiente, ésta no se ha entregado para la realización del mismo. Al no contar con la máscara a partir de la cual se comenzaría este trabajo, conseguir una aproximación de lo que sería la máscara de entrada se convierte por tanto en uno de los principales objetivos. Este paso es estrictamente necesario, ya que sin la máscara sería imposible continuar el desarrollo.

-Observar las características del recipiente y analizar cuál de sus propiedades puede resultar beneficiosa para el trabajo a la hora de elaborar los desarrollos.

-Estudiar métodos a través de los cuales se pueda dividir el contenido del recipiente y realizar agrupaciones de las zonas homogéneas. Contemplar las posibles condiciones a las que puede estar sometido el objeto de estudio: distancia, orientación, ángulo etc.

-Poder localizar y delimitar el área correspondiente al líquido que se encuentra dentro del recipiente. Una vez localizado, desarrollar un método a través del cual se pueda calcular el nivel que contiene, alcanzando así el objetivo final de este trabajo.

Todos estos puntos se irán evaluando y exponiendo a lo largo de los siguientes capítulos.

## 1.3. Organización de la memoria

La memoria consta de los siguientes capítulos:

- Capítulo 1: Introducción 1.
- Capítulo 2: Estado del arte 2.
- Capítulo 3: Diseño y desarrollo 3.
- Capítulo 4: Evaluación y resultados 4.
- Capítulo 5: Conclusiones 5.
- Bibliografía.

## Capítulo 2

# Estado del arte

### 2.1. Introducción

En este capítulo se procederá a investigar las áreas de estudio a través de las cuales se va a enfocar este proyecto, así como las herramientas utilizadas. Respecto a las áreas, se centrará por un lado en la investigación de la detección por aproximación, y por otro en conocimientos relacionados con la segmentación y el clustering. En el apartado de herramientas se explicará el programa utilizado en este proyecto.

### 2.2. Áreas de estudio

Para la organización y la evolución de todo el procedimiento que va desde que la máscara es utilizada como parámetro de entrada, hasta el momento en que se consigue obtener el nivel de llenado del recipiente, se centrará la investigación especialmente en los siguientes puntos: algoritmos y desarrollos relacionados con la detección por aproximación, la segmentación y el clustering. Se han elegido estas áreas ya que parecen las más convenientes y las que mejor se pueden adaptar a las necesidades de este trabajo.

#### 2.2.1. Detección por aproximación

Como se ha comentado en 1.2, es necesario poder simular cómo sería la máscara que se proporcionaría como entrada para la realización de este proyecto. El campo de la detección ofrece un gran abanico de posibilidades y tiene múltiples vías de estudio. Sin embargo, en este caso particular, se va a reducir el entorno de la detección a algo más concreto: la detección por aproximación. Esto es así, porque se conoce la posición del recipiente respecto a la imagen y porque al ser un objeto conocido se conocen sus características. Esto aporta grandes ventajas, facilitando la detección. Debido a esto, el estado del arte respecto a la detección se centrará especialmente dos vías distintas:

- Por una parte se estudiará la detección de bordes del algoritmo Canny. Este algoritmo tiene como finalidad encontrar los bordes que aparezcan en una imagen. Su funcionalidad se basa en el estudio de la primera derivada, ya que esta tiene resultados no negativos en las

zonas donde se produce un cambio de intensidad. Este cambio de intensidad, por lo general brusco, se corresponde con la detección de un borde en la imagen. Por lo que será de gran interés hallar el gradiente de cada píxel, así como su orientación, para conocer la localización exacta de los bordes. Previamente, se realiza un suavizado, normalmente Gaussiano, para reducir el posible ruido de la imagen y facilitar el cálculo de los gradientes [1]. En la figura 2.1 se muestra una imagen de ejemplo y la misma imagen tras aplicar el algoritmo de Canny.




Figure 2.1: Imagen algoritmo de Canny [1].

-Por otro lado, se investigarán también los contornos activos o snakes. Estas técnicas fueron desarrolladas a finales de la década de los 80. Son algoritmos iterativos que necesitan tres parámetros para su ejecución: la imagen a procesar, una máscara y un número de iteraciones. Los contornos activos se basan en el uso de una máscara propuesta inicialmente, la cual va minimizando su energía en cada iteración hasta conseguir adaptarse lo mejor posible al perfil del objeto. La máscara se diseña con un contorno semejante al objeto, o al menos intuitivo, para que pueda ajustarse lo máximo posible y obtener un resultado óptimo. La forma de los contornos activos difiere en base a la silueta del objeto que se desee detectar, y pueden ser cerrados o abiertos [2]. En la figura 2.2 se muestra a la izquierda un ejemplo de la imagen original y de la máscara que va a iterar sobre ella en color rojo; y la imagen resultante tras aplicar los contornos activos a la derecha.




Figure 2.2: Imagen algoritmo de Contornos Activos [3].

Para aumentar la efectividad de la detección del recipiente se estudian sus características. Respecto a las zonas de interés del bote se pueden descartar las zonas correspondientes a los tapones, ya que no ofrecen ningún dato de utilidad respecto al nivel de llenado. En este caso, se utilizarán nuevamente técnicas de detección para poder localizarlas y eliminarlas del objeto de estudio. Al ser el recipiente de estructura conocida se puede observar que los tapones destacan sobre el resto del objeto por su color. Por lo tanto, en este punto, el tipo de detección que se necesitará aplicar será una detección relacionada con un espacio de color. Se ha elegido el espacio de color HSV para esta empresa. El entorno de color HSV consta de los siguientes tres parámetros:

- Hue: Se relaciona con el matiz o el tono del color y se representa entre un rango que va desde los  $0^\circ$  hasta los  $360^\circ$ . Cada grado viene definido por una longitud de onda

determinada, que es el resultado de las distintas combinaciones entre los tres colores primarios.

- **Saturation:** Este parámetro se corresponde con la pureza del color. Se representa con porcentajes del 0 % al 100 % o con valores comprendidos entre 0 y 1. Siendo cero el extremo en el que la cantidad de luz o brillo es inexistente, y 1 la máxima excitación que puede llegar a alcanzar.
- **Value:** También conocido como luminancia, representa la intensidad de luz que caracteriza a un píxel. Estima sus valores, al igual que la saturación, entre 0 y 1.

En la figura 2.3, se ofrece una imagen del cono que representa el sistema de color HSV.




Figure 2.3: Cono representativo del sistema de color HSV [4].

Las propiedades de HSV se utilizan mucho en estudios de color de imágenes, ya que mediante la combinación de los tres parámetros previamente explicados se puede llegar a resultados muy similares a los que se corresponden con la visión de las personas. El sistema HSV permite, por tanto, que se pueda establecer una similitud muy relevante entre su funcionamiento y el del ojo humano. Debido a esta funcionalidad, se han podido hacer grandes avances en el procesamiento de imágenes y el estudio de la percepción visual del color en ellas [5].

### 2.2.2. Segmentación

Las técnicas de segmentación son aquellas que se encargan de dividir la imagen en fragmentos de un tamaño lo suficientemente pequeño como para poder obtener de ellos datos de interés. Esta división puede ir tanto de regiones de mayor o menor tamaño, como al mínimo exponente, el píxel. La segmentación se puede abarcar desde múltiples puntos, pero en este caso, el estudio se centrará en aquellas segmentaciones que se basen en características comunes. Se ha mencionado el píxel como elemento básico, lo que hace que en ocasiones como la de este estudio, sea demasiado pequeño si se quiere tomar como referencia. Sin embargo, se va a introducir el término de superpíxel. Se considera un superpíxel a aquella región que está formada por una agrupación de píxeles que poseen las mismas propiedades y que son homogéneos entre sí [6]. De esta manera, se pueden obtener datos de interés sin necesidad de llevar a la segmentación a un nivel de detalle más pequeño. La segmentación basada en

superpíxeles es de gran utilidad y eficiencia, por lo que se evaluarán métodos relacionados con ellos para esta investigación:

▪ ***Simple Linear Iterative Clustering (SLIC):***

Es una técnica que trabaja con superpíxeles complementándolos con procesos de clustering. Para la parte en la que se contempla usar métodos de clustering en este algoritmo, se usa una adaptación de k-means con las siguientes diferencias. En general el método k-means busca proximidad por vecindad a lo largo de toda la imagen. En este caso, sin embargo, se limita la búsqueda a un espacio proporcional al tamaño del superpixel con el que se esté operando. En la figura 2.4 se contemplan las distinciones entre ambas búsquedas.




Figure 2.4: Métodos de búsqueda K-Means: (a) Búsqueda general K-Means, (b) Adaptación búsqueda K-Means en una región limitada [7].

Además, al contar con un área ponderada máxima de búsqueda se pueden combinar las propiedades de proximidad espacial y de color más fácilmente, ayudando a tener un control más efectivo sobre el tamaño de los superpíxeles y haciéndolos más compactos y robustos [7].

Esta combinación entre color y espacio es un factor muy importante, ya que es uno de los parámetros principales en los que se basa el algoritmo. A este parámetro se le identificará mediante la letra  $m$ . El otro parámetro que se debe añadir para que el algoritmo sea eficiente es el número deseado de superpíxeles en los que queremos dividir la imagen. El número de superpíxeles ( $K$ ), está estrechamente relacionado con el parámetro  $m$ . El número  $K$  debe de ser suficientemente grande, especialmente si el valor de  $m$  es reducido. La importancia de obtener un gran número de superpíxeles es la siguiente: en cuantas más regiones se consiga dividir la imagen, mayor será la precisión de la detección. Se podrán juntar así con más facilidad las zonas homogéneas y detectar los bordes con mayor exactitud.

Como ya se ha comentado, el color y la posición son de vital importancia para este algoritmo. La generación de los superpíxeles por clustering se hace en un espacio de cinco dimensiones, que se denomina labxy. Las tres primeras letras se corresponden con el espacio de color de CIELAB, uno de los más utilizados actualmente en los estudios relativos al color. Mientras que las dos siguientes, xy, identifican la posición del píxel. Considerando que el número de superpíxeles es  $K$ , y que una imagen cuenta con  $N$  píxeles, el tamaño medio aproximado de cada superpíxel será entonces de una dimensión correspondiente a  $N/K$ . Al inicio del algoritmo se escogen  $K$  clusters de superpíxeles cuyos centros se encuentran en  $[l_k, a_k, b_k, x_k, y_k]$ , siendo  $k$  un valor comprendido entre 1 y  $K$ , y estando distribuidos en intervalos regulares de cuadrícula ( $S$ ). Dado que se sabe que la extensión de cada superpíxel

es aproximadamente uniforme, se sabe con seguridad por tanto que los píxeles se encuentran en un determinado cluster de área conocida entorno al centro correspondiente al plano xy [8]. Es decir, esta área será la zona de búsqueda dónde se seleccionen los píxeles más cercanos al cluster en cuestión.

En el espacio de color de CIELAB se usan distancias Euclidianas ya que se obtienen resultados bastante significativos. Sin embargo, estos resultados son óptimos únicamente cuando se trabaja con distancias pequeñas. Por lo que en los casos en los que las distancias entre los píxeles puedan ser algo mayores, el método por distancias Euclidianas no sería válido. Como el entorno no es únicamente un espacio de color, si no también de posición, se usa por ello la fórmula 2.1 en el espacio 5D de labxy [8].

$$\begin{aligned}
 d_{lab} &= \sqrt{(l_k - l_i)^2 + (a_k - a_i)^2 + (b_k - b_i)^2} \\
 d_{xy} &= \sqrt{(x_k - x_i)^2 + (y_k - y_i)^2} \\
 D_s &= d_{lab} + \frac{m}{s} d_{xy}
 \end{aligned} \tag{2.1}$$

Como resultado de dicha fórmula se obtiene  $D_s$ , que es la suma de la distancia del espacio de color lab y la suma del plano xy. La suma del plano xy a su vez queda normalizada por la cuadrícula  $S$  y multiplicada por la variable  $m$  introducida al principio de este apartado, la cual aporta la propiedad a los superpíxeles de que sean más compactos. Si  $D_s$  es menor que la distancia estipulada inicialmente al píxel, el valor de  $D_s$  será el que defina a partir de este momento la distancia. Este proceso se realizará en todos los clusters y durante un número determinado de iteraciones, lo que hará que todos los píxeles se vayan distribuyendo a sus vecindarios convenientes.

■ ***SuperPixel Density Based Spactial Clustering of Applications with Noise (SPDBSCAN):***

Es un algoritmo rápido y efectivo que trabaja con una gran cantidad de datos, seleccionando y agrupando a los que pertenecen a la misma zona homogénea, distinguiendo los bordes de las siluetas y separando el ruido del resto de datos útiles [9]. Se encarga de la agrupación de aquellos superpíxeles que cuentan con propiedades muy parecidas o semejantes. Es decir, es un algoritmo que toma como parámetro de entrada una imagen dividida en regiones más pequeñas, como los superpíxeles, y cuya funcionalidad es unirlos de la manera más óptima posible para obtener regiones de mayor tamaño que sigan compartiendo propiedades y teniendo características en común. Además de la imagen segmentada se añade otro parámetro que representa un umbral que está relacionado con las diferencias de color del espacio lab. Este parámetro es fundamental debido a que trabaja con espacios de color, propiedad principal a través de la cual se puede diferenciar unas regiones de otras. La elección de este umbral puede tener resultados muy significativos en el resultado de la imagen ya que indica la tolerancia que tienen los superpíxeles en base al color para permanecer, o no, en el mismo cluster [10].

### 2.2.3. Clustering

Respecto al clustering, es una técnica de agrupamiento que se basa por lo general en algoritmos matemáticos y que se suele usar en minería de datos. Se utilizarán modelos de clustering en este proyecto para poder medir con más exactitud la semejanza entre los datos y poder distinguir con más facilidad las distintas regiones que se van a procesar. Hay varios algoritmos relacionados con el clustering, pero este estudio se va a centrar en la investigación de los algoritmos K-Means y Fuzzy C-Means. Ambos basan las decisiones de asignar un elemento a un cluster o a otro en función de las distancias y sus medias. Las diferencias entre dichos algoritmos son pequeñas, pero pueden ser determinantes.

A pesar de su parecido procedimiento se distinguen por lo siguiente: K-Means cuando se encarga de asignar un elemento a un cluster lo hace de manera exacta, es decir, pertenece a un cluster o a otro, pero no a ambos. Este procedimiento es muy útil y efectivo en los casos en los que los límites de las regiones están bien definidos. El caso de Fuzzy C-Means, sin embargo, es más flexible. Esto quiere decir que se contempla la posibilidad de que un elemento pueda pertenecer a dos clusters al mismo tiempo. Este tipo de situaciones tienen lugar especialmente en entornos con algún tipo de ruido o con límites poco definidos o difusos. En el capítulo adyacente se explicará más en detalle estos algoritmos y se estudiará cual resulta más eficaz para la finalidad de este proyecto.

## 2.3. Herramientas

### 2.3.1. Matlab

Matlab es un entorno de Software que ofrece grandes facilidades a nivel matricial y operacional, así como capacidades para la creación de funciones o implementaciones de algoritmos. Cuenta con un lenguaje de programación propio y además, consta de un simulador en el que poder practicar las funcionalidades de los scripts ejecutados. Es utilizado en investigaciones y en procedimientos relacionados con el área de procesamiento de imágenes, por lo que se ha elegido este software para realizar este proyecto [11]. Se han utilizado las versiones R2016b y R2018.

## 2.4. Conclusiones

Se ha realizado un preámbulo acerca de los métodos de estudio en los que se va a centrar este proyecto, conociendo algunas de las técnicas que se van a emplear, así como algoritmos que se van a evaluar para su utilización en función de su eficiencia. En los capítulos siguientes se abordará todo lo anterior aplicándolo al caso de estudio que se desarrolla en este proyecto. Se ha aportado además una pequeña introducción acerca de Matlab, la principal herramienta utilizada para el desarrollo de este trabajo.



## Capítulo 3

# Diseño y desarrollo

### 3.1. Introducción

A partir del estado del arte se ha establecido un acercamiento hacia las distintas técnicas generales que tienen influencia sobre este proyecto. Ahora, por otra parte y para complementar la información previa, se procederá a investigar más a fondo los algoritmos que se utilizan en cada una de las técnicas comentadas en el capítulo anterior<sup>2</sup>. El diseño de este trabajo se ha dividido en los algoritmos que se ofrecen a continuación, enfocados a la detección, la segmentación y el clustering, así como en los procedimientos llevados a cabo para la detección del nivel de llenado.

### 3.2. Visión general

A través de la figura 3.1, se ofrece la visión de un diagrama de bloques donde quedan recogidas todas las etapas de algoritmos y operaciones por las que pasa una imagen inicial de entrada hasta alcanzar el nivel de llenado como resultado final.

En el esquema de la figura 3.1 se muestra de manera sintetizada todos los procedimientos que se desarrollarán posteriormente en función de las áreas de desarrollo que abordan. Por una parte, en la etapa inicial de detección se encuentran los algoritmos de contornos activos y los relacionados con el entorno de color HSV. Posteriormente tiene lugar la fase en la que se aplican los algoritmos destinados a la segmentación y el clustering: SLIC, DBSCAN y Fuzzy C-Means. Para completar los procesos anteriores, se termina con la obtención del nivel de llenado, el cual se obtendrá mediante un eje de orientación y dos contadores de longitud.

### 3.3. Algoritmos de detección por aproximación

#### 3.3.1. Contornos Activos

Como se ha comentado en los objetivos de este proyecto 1.2, se utiliza de base una máscara del recipiente que se proporciona inicialmente. Para simular una aproximación de dicha máscara se procede a crear un entorno ideal para la detección del objeto. Es decir, se




Figure 3.1: Diagrama de bloques algoritmos

utilizan imágenes con un fondo homogéneo y con poco ruido, para que a la hora de aplicar un algoritmo de detección este se pueda asemejar lo más posible a lo que sería la máscara proporcionada del recipiente. En esta situación, el algoritmo que más encajaba con estas condiciones es el de contornos activos, ya que ofrece una mejor adaptación a la detección de este estudio, respecto a la detección por Canny. Como se saben las características del recipiente y donde se encuentra localizado dentro de la imagen, se utilizará una máscara rectangular centrada de un tamaño algo superior a las proporciones del recipiente.




Figure 3.2: Figuras contornos activos: (a) Máscara inicial a partir de la cual se itera, (b) Máscara tras 250 iteraciones, (c) Máscara tras 500 iteraciones

En el caso de estudio que se propone en este proyecto se trabajará con un contorno cerrado, y con un número de iteraciones lo suficientemente elevado como para alcanzar resultados favorables con los que se pueda seguir desarrollando el resto del experimento. En la figura 3.2, se muestran tanto la máscara usada en el desarrollo, como la evolución que va teniendo la imagen al aumentar el número de iteraciones.

### 3.3.2. Detección zonas de color

Una vez se ha generado la máscara a través de los contornos activos para detectar el recipiente, se procede a reducir la región de estudio para facilitar la detección del líquido. Para ello se procede a crear una nueva máscara más homogénea del recipiente a partir de la eliminación de las zonas verdes, es decir, de los tapones que se encuentran en la parte superior. La técnica que más se ha adaptado a estas necesidades ha sido la que se ha basado

en el estudio del modelo de color HSV. Se utilizará esta técnica para modificar una imagen en formato RGB y transformarla en otra imagen dónde el valor de los píxeles que la componen se mide en función de los tres parámetros explicados en 2.2.1: Hue (Tonalidad), S (Saturación) y V (Luminancia).

Debido a que la parte que queremos eliminar de la imagen se corresponde con el verde, se elegirá, como herramienta principal el parámetro que mejor se ajuste a esta detección. En la figura 3.3 se aprecia la influencia de cada canal sobre el recipiente de la imagen. Claramente se observa que el parámetro que servirá de mayor utilidad para el propósito planteado será la saturación, debido al contraste que ofrecen las zonas verdes respecto al resto de regiones. Por lo tanto, será el canal de la saturación el utilizado para poder detectar estas zonas y ser capaces de aislarlas del resto del objeto.




Figure 3.3: Imagen de los tres canales del entorno de color HSV sobre el recipiente

Al contar por un lado con la silueta total del objeto obtenida a través de los contornos activos, y de la máscara que a su vez elimina las zonas no deseadas para el estudio mediante el modelo de color HSV, se procede a generar la máscara definitiva. Para ello se multiplicarán ambas máscaras, siendo nulos los valores correspondientes a las zonas verdes que se quieren eliminar. De esta manera se elabora la máscara final del recipiente a partir de la cual se realizarán los siguientes estudios y algoritmos para conseguir detectar el nivel de llenado.

## 3.4. Algoritmos de segmentación y clustering

### 3.4.1. Simple Linear Iterative Clustering

Inicialmente, para la detección de la región correspondiente al líquido se valoró únicamente superpíxeles. Esta técnica, aunque se acercaba a soluciones aceptables, no ofrecía resultados del todo óptimos. Se estudió entonces un algoritmo que incluía a los superpíxeles combinados con una aproximación por clustering. Este algoritmo comentado en 2.2.2 se denomina SLIC: Simple Linear Iterative Clustering.

Se ha mencionado la existencia de un parámetro denominado  $m$ , el cual combina los factores de color y espacio, por lo que su correcta elección es fundamental. Se le suelen

asignar valores encontrados entre 5 y 40. En este caso de estudio se procede a usar el valor 5, ya que es el que se ha demostrado empíricamente que se ajusta mejor a las propiedades del recipiente que con valores de mayor magnitud. El otro parámetro que se ha comentado que hay que añadir a este algoritmo es  $K$ , es decir, el número de superpíxeles en el que se quiere que la imagen sea segmentada. Al haber elegido un valor pequeño para  $m$ , se deberá de escoger un valor grande para  $K$ , ya que el algoritmo ofrece mejores resultados si  $K$  es bastante superior a  $m$ . El valor de  $K$  en este estudio se ha considerado que sea de 2000 píxeles. Un número lo suficientemente elevado para que los superpíxeles obtenidos tengan información relevante que aportar a la hora de la segmentación de la imagen.

Mediante la elección de estos parámetros y el funcionamiento del algoritmo explicado en el estado del arte 2.2.2, se utilizarán los resultados obtenidos para poder efectuar el siguiente algoritmo.

### 3.4.2. SuperPixel Density Based Spactial Clustering of Applications with Noise

Una vez finalizado el algoritmo de SLIC, se utiliza el algoritmo SPDBSCAN: SuperPixel Density Based Spactial Clustering of Applications with Noise.

Con el algoritmo de SLIC se consigue dividir la imagen en un número determinado de superpíxeles agrupados por vecindad. En el caso de SPDBSCAN, después de haber realizado el paso anterior se procede a la agrupación de aquellos superpíxeles que cuentan con características comunes. De esta manera se pueden ir generando áreas mayores correspondientes a las distintas grandes partes en las que se divide el recipiente. Para estudiar la diferenciación que existe entre unos valores u otros se introducen como parámetros de entrada de SPDBSCAN los parámetros devueltos por SLIC (la imagen con todos los clusters etiquetados, características de color correspondiente a cada región, y una matriz cuyo contenido indica aquellas coordenadas de los puntos que están conectados). Además, como se introdujo en el estado del arte, se incluye un nuevo parámetro, al que se le denomina con la letra  $E$ , y que representa un umbral que está relacionado con las diferencias de color del espacio lab. Este parámetro es fundamental debido a que trabaja con espacios de color, propiedad principal a través de la cual se va a poder diferenciar el líquido del resto del recipiente vacío. La elección del umbral de  $E$  puede tener resultados muy significativos en el resultado de la imagen ya que aporta información sobre la tolerancia con la que cuentan los píxeles para pertenecer a un cluster o a otro [10]. Determinar este factor es de gran importancia, ya que aunque la variación de  $E$  sea pequeña, los cambios resultantes son muy notorios como se puede observar en las imágenes de la figura 3.4.

En las imágenes que se observan en la figura 3.4 se fusionan la imagen original enmascarada y la malla de superpíxeles resultantes de la aplicación del algoritmo SPDBSCAN. Cabe destacar que para umbrales bajos, los superpíxeles se agrupan inicialmente como figuras hexagonales. Esto se debe a que en el algoritmo SLIC se incializan las regiones de interés tomando como patrón un hexágono. El hecho de utilizar esta figura geométrica, en vez de tomar de referencia un cuadrado, facilita la posibilidad de encontrar coincidencias entre los




Figure 3.4: Resultados obtenidos mediante SLIC y SPDBSCAN con diferentes umbrales: (a)  $E=1$ , (b)  $E=5$ , (c)  $E=10$

superpíxeles y poderlos asociar con mayor robustez al mismo cluster. Cuando el umbral va aumentando, se visualiza una disociación de estas formas hexagonales que se han comentado. Esto es consecuencia de la necesidad de aumentar el tamaño de los píxeles para que se vayan ajustando a las grandes zonas de interés, que destacan respecto a los detalles menores. Ya que con umbrales pequeños los resultados obtenidos no detectan regiones determinantes, y que con umbrales más elevados, los resultados ignoran las regiones intermedias del bote que son precisamente las que interesan, se elige un umbral moderado que se pueda amoldar a las zonas de interés. Este umbral se ha evaluado en numerosas pruebas y se ha determinado utilizar en todos los casos de estudio de este trabajo el valor 5, ya que es el que mejor se ha adaptado con los resultados deseados.

Al aplicar SLIC y DBSCAN se visualiza la diferenciación de las distintas regiones del bote. Para aumentar la exactitud, agrupar pequeñas zonas que han quedado fuera de las grandes partes homogéneas, y poder estudiar de manera más visual los resultados se ejecutará otro nuevo algoritmo: Fuzzy C-means.

### 3.4.3. Fuzzy C-Means

En el estado del arte se valoraba la utilización de las técnicas K-Means y Fuzzy C-Means para este estudio. Ambos son algoritmos de clustering muy similares. Se han estudiado sus diferencias, llegando a las siguientes conclusiones: K-Means es un algoritmo que se adapta mejor a imágenes con regiones bien definidas, mientras que Fuzzy C-Means es mejor para imágenes que puedan contener delimitaciones de bordes difusas. Debido a que en este trabajo no nos encontraremos sólo con clusters únicos y bien delimitados, se utilizará el algoritmo Fuzzy C-Means en vez de K-Means, aportando así mayor flexibilidad a los resultados [12].

Fuzzy C-Means es un algoritmo que estudia todos los elementos de una imagen y los divide en  $C$  clusters. Asocia cada punto a un cluster en función del grado de vecindad que posean. Se recuerda que este grado puede ser no sólo 0 (no pertenece al cluster) o 1 (pertenece), si

no que puede alcanzar valores intermedios, perteneciendo a más de un cluster a la vez. En cada iteración, la función de este algoritmo se va minimizando hasta ofrecer finalmente la localización más óptima de cada cluster [13].

En este proyecto el número de clusters ( $C$ ) se define mediante el estudio de los distintos niveles de grises que se puedan apreciar en el recipiente. Por lo que si en el recipiente se observan tres niveles distintos de grises, el algoritmo Fuzzy centrará su desarrollo en tres clusters, ofreciendo así un ajuste más preciso para la agrupación de los datos. Para apreciar en cuántos niveles de grises se agrupan los valores de los píxeles de la imagen se realiza un análisis a través de un histograma. Se puede visualizar en la figura 3.5 como destacan dos o tres niveles, en función de los picos que queden representados. En el caso del histograma (a), el número de clusters, es decir, el valor de  $C$ , será 2, y por consiguiente tomará el valor 3 para el caso del histograma (b).

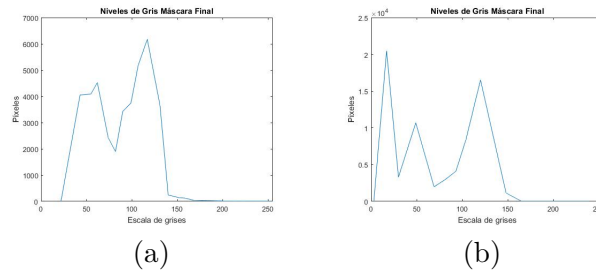


Figure 3.5: Histogramas Niveles de Grises de la Máscara Final: (a) Histograma con dos niveles de gris, (b) Histograma con tres niveles de gris.

Como este algoritmo se aplica después de haber empleado SLIC y SPDBSCAN sobre la imagen, las regiones están parcialmente definidas. Por lo que será fácil interpretar por parte de Fuzzy las regiones definitivas. Después de este proceso las zonas quedarán diferenciadas con mayor precisión, menos ruido y organizadas únicamente en el número de clusters deseados. Para limpiar las pequeñas inexactitudes resultantes de todos los algoritmos aplicados previamente, se somete a las imágenes resultantes a una serie de procesos de erosión y dilatación para eliminar las posibles imperfecciones que contenga la imagen. La erosión y la dilatación son operaciones morfológicas que a partir de un elemento estructural dado eliminan píxeles de un contorno, o aumentan los bordes del mismo, respectivamente [14]. Al finalizar este proceso de limpieza ya se tendría la imagen final donde se podrá visualizar claramente la diferenciación del líquido respecto al resto del recipiente.

En este punto se avanza a la siguiente etapa del proyecto que contiene el objetivo final de este estudio: el cálculo del nivel de llenado.

### 3.5. Nivel de llenado

Una vez aplicados todos los algoritmos previos, se inicia la etapa donde se va a conseguir el objetivo de este trabajo: obtener el nivel de llenado del recipiente. Antes de proceder a la obtención de dicho resultado, es importante tener en cuenta que las imágenes pueden estar torcidas, inclinadas, o al menos no completamente rectas. En la figura 3.6 se puede ver una de

las desviaciones sobre las que se está tratando. Esto produciría un cambio en los resultados del estudio, por lo que es un punto importante que abordar.



Figure 3.6: Ejemplo de la posible desviación que puede tener una imagen

A lo largo de este proyecto se ha intentado poner solución a este aspecto mediante el estudio de las siguientes posibilidades:

Inicialmente, al conocer las propiedades del recipiente, y sabiendo que a lo largo del mismo se encuentran presentes unas líneas de medida se decidió utilizarlas de referencia. La idea era estudiar su posición respecto al eje horizontal de la imagen y medir así su grado de desviación. La técnica que mejor encaja con esta idea es la transformada de Hough, ya que permite detectar y localizar las líneas horizontales o verticales en una imagen, dependiendo de la búsqueda deseada. El problema que se presentó al aplicar esta técnica fue que las líneas no eran detectadas. Esto se debe a que no eran completamente rectas, si no ligeramente curvadas debido a la forma redondeada del recipiente. Por lo que se descartó la iniciativa de utilizar la transformada de Hough para esta finalidad.

Por otro lado se estudió la idea de utilizar una imagen de referencia, la cual fuese ideal, es decir, que estuviese recta y bien orientada. Se pretendía, a través de homografías, conseguir orientar el resto de las imágenes de estudio en base a la de referencia. La funcionalidad de las homografías es calibrar y dimensionar una imagen, tomando puntos y coordenadas de otra imagen como referencia. Esta técnica tiene muy buenos resultados sobre imágenes planas, pero como se pudo comprobar, no es efectiva para las imágenes de estudio que se utilizan en este proyecto.

Finalmente, se decidió utilizar un eje que cortase verticalmente al recipiente para conocer su orientación. Este procedimiento si alcanzó resultados efectivos y por tanto será el que se explicará a continuación. Para trazar el eje, se toma como base la máscara binaria resultante de la imagen obtenida a partir de las máscaras de contornos activos y de detección por el entorno de color HSV. Sobre esta imagen se trazan de manera horizontal una serie de líneas rectas que van de un extremo a otro del recipiente. Este trazado se realiza con un bucle que recorre varias de las filas que forman parte del recipiente, acumulando su longitud y sus correspondientes puntos medios. A partir de todos los puntos medios resultantes de las rectas trazadas, se calcula una recta de aproximación que los atraviesa. Para su cálculo se utilizan las herramientas de *polyfit*, *linspace* y *polyval*, disponibles las tres en Matlab.

Mediante la combinación de las tres se puede generar una recta que se ajuste de manera equivalente a todos los puntos medios obtenidos. Esta recta de aproximación resultante será el eje de orientación en base al cual se podrá continuar con el estudio a pesar de que la imagen esté girada. En la figura 3.7 se puede observar como se presentan dos posibles resultados. El resultado (a), que se corresponde con un eje prácticamente recto, y por otra parte el resultado (b), donde es notable que el recipiente está girado, con su eje de orientación trazado consiguientemente con la misma orientación que el objeto.




Figure 3.7: Ejes de orientación: (a) Eje correspondiente a un objeto recto, (b) Eje vinculado a un objeto girado,

Ahora que queda identificado el eje de orientación se puede pasar a calcular el nivel de llenado. Para este cálculo se necesita saber cuánto miden en la imagen tanto el bote, como la región del líquido. Aquí es donde el eje de orientación cumple su función. Para la parte de medir la longitud del bote, el eje será utilizado de tal forma en la que se recorrerán todas sus coordenadas. Como la máscara sobre la que se ha trazado el eje es binaria, los valores de las coordenadas correspondientes al bote tomarán el valor 1, y las correspondientes al fondo el valor 0. Por lo que al recorrer el eje, se acumularán todos los píxeles con valor 1 en una variable. El número total que contenga esta variable al finalizar el recorrido del eje será la longitud que posee el bote en la imagen. Se repetirá la misma operación de un modo parecido con la parte del líquido. En este caso, la imagen no es binaria, si no que cuenta con dos o tres colores distintos, dependiendo de las clases que se hayan definido en el algoritmo de Fuzzy C-means, más el color correspondiente al fondo. En este caso, al conocerse las propiedades de la imagen, se sabe que empezando a recorrer el eje desde la parte inferior los primeros píxeles encontrados corresponderán al fondo y no al objeto. De la misma forma, se sabe que cuando se produzca un cambio en el valor del píxel, el eje de orientación se encontrará a la altura de la zona de llenado. En este momento se inicializará el contador que se encarga de acumular los valores de llenado. Dicho contador seguirá sumando unidad tras unidad hasta que el valor de los píxeles vuelva a cambiar. Esto significará que el eje de orientación ha atravesado ya la zona del líquido y se encuentra actualmente en otra zona del bote que no interesa al estudio.

Al obtener los resultados de ambos contadores, es decir, las longitudes del bote y de la zona de llenado en la imagen, se averiguará mediante la fórmula 3.1 el nivel de llenado real del recipiente. Esta asociación es posible ya que el recipiente es conocido y sabemos su



longitud real.

$$N_{llenado} = \frac{d_{liq} \cdot Lr_{real}}{Lr_{ima}} \quad (3.1)$$

Mediante la longitud que abarca la zona del líquido ( $d_{liq}$ ), la longitud real del recipiente ( $Lr_{real}$ ) y la longitud del recipiente en la imagen ( $Lr_{ima}$ ), se consigue finalmente el objetivo de este proyecto: La obtención del nivel de llenado del recipiente ( $N_{llenado}$ ).



## Capítulo 4

# Evaluación

### 4.1. Introducción

En este apartado de la memoria se procederá a estudiar y comentar los resultados obtenidos a lo largo de todo el proceso de desarrollo de este trabajo. Se detallará el material utilizado desde el primer momento y se analizarán todas las soluciones a las que se han llegado por los distintos métodos evaluados.

### 4.2. Marco de evaluación

Para evaluar todos los procesos y algoritmos llevados a cabo durante este proceso ha sido necesario contar con un gran número de imágenes para poder analizar su efectividad. Como el objetivo de este proyecto es el de detectar el nivel de llenado de un recipiente, se estudian imágenes con distintos niveles de llenado para comprobar que los algoritmos son eficientes en todos ellos. Se han evaluado seis niveles distintos de llenado, que van desde los 90ml hasta los 310ml. Cada nivel ha sido evaluado con diez imágenes. Por lo que el cómputo total de imágenes usadas para este estudio es de 60. Dentro de este número se han utilizado imágenes que difieren en cuanto a distancia, orientación y lado de observación. Es decir, se han tomado fotografías cerca y lejos; rectas y giradas; con el objeto desde su parte anterior y su parte posterior. En la figura 4.1 se ofrecen imágenes variadas que forman parte del dataset utilizado para las pruebas y ejecuciones de este trabajo.

Las imágenes referentes al nivel de llenado (a), ofrecen una visión del recipiente desde un punto de vista anterior y posterior con un volumen de 90ml; las imágenes del nivel de llenado (b) se corresponden con una imagen recta y otra mal orientada (girada) a 185ml; respecto al nivel de llenado (c) se visualizan los recipientes a diferentes distancias con un nivel de llenado equivalente a los 310ml.

### 4.3. Pruebas y resultados

Una vez desarrollados todos los algoritmos necesarios para detectar el nivel de llenado del recipiente translúcido de estructura conocida, se procede a entrar en la etapa de pruebas.

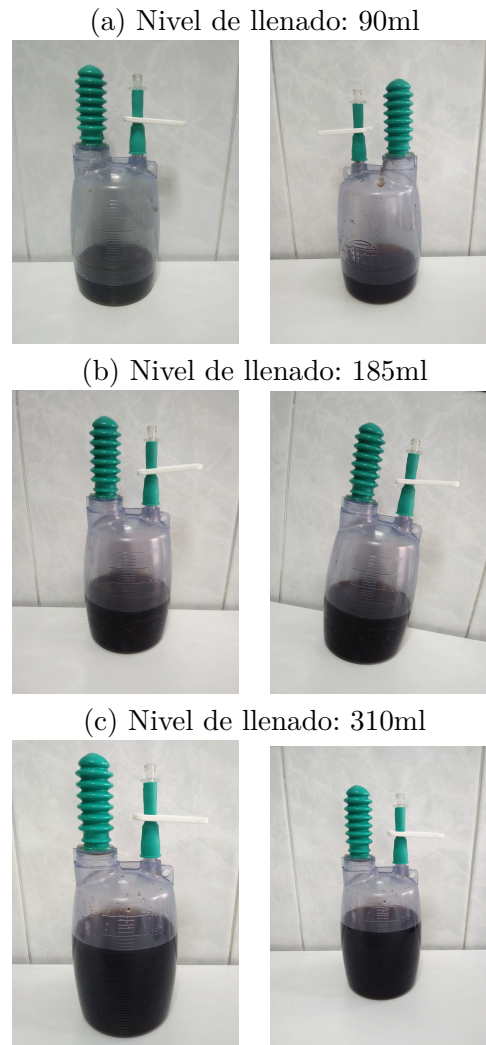


Figure 4.1: Imágenes con características distintas en diferentes niveles de llenado

A parte de los resultados finales donde se detectan los niveles de llenado, se van a visualizar y comentar también los resultados que se han ido obteniendo tras cada desarrollo. Uno de los primeros pasos que se decidió dar para el inicio de este proyecto fue la detección por aproximación del recipiente a través de contornos activos.




Figure 4.2: Máscara resultante tras aplicar contornos activos con 1000 iteraciones

En la figura 4.2 se muestra el resultado tras aplicar un algoritmo de contornos activos de 1000 iteraciones. Se ha considerado empíricamente que este número de iteraciones es el que mejor se adapta a las imágenes.

Posteriormente, y siguiendo con las máscaras, se aplicó una detección a través del entorno de color HSV para localizar a través de la saturación las zonas no deseadas del objeto. Es decir, se crea una máscara que localice las zonas correspondientes al color verde, para que a continuación sea posible su eliminación. En la figura 4.3 se muestra tal resultado .



Figure 4.3: Máscara resultante tras aplicar la técnica de color HSV

Mediante la combinación de ambas máscaras, y negando los valores correspondientes a la máscara HSV se consigue llegar a la máscara definitiva sobre la cual se desarrollarán el resto de algoritmos. Esta máscara es la máscara resultante tras aplicar los dos procedimientos de detección comentados anteriormente. El resultado final de la máscara del recipiente se encuentra recogido en la figura 4.4.




Figure 4.4: Resultado de la máscara final

Una vez conseguida la máscara final se puede proceder a realizar las pruebas correspondientes a los algoritmos de segmentación. Ya se ha explicado el funcionamiento de los algoritmos de SLIC y SPDBSCAN, así como la eficacia que pueden llegar a tener sus resultados si se fusionan. Además, para proporcionar robustez se incorporó posteriormente también

el algoritmo de Fuzzy C-Means. El objetivo de fusionar todos estos desarrollos era poder llegar a un resultado donde la zona del líquido fuese detectada y diferenciada del resto del contenido del recipiente. Tras todos estos pasos el resultado se puede visualizar en la figura 4.5.




Figure 4.5: Resultado final tras aplicar el algoritmo de Fuzzy C-Means

Aunque ya se han visto ejemplos del eje de orientación en el capítulo anterior, ha sido únicamente sobre la máscara del recipiente. En la figura 4.6, sin embargo, se puede observar como el eje de orientación cruza también por la zona de llenado. Llegar a este resultado es de vital importancia, ya que a partir de las medidas obtenidas con el eje de orientación se puede llegar a definir el objetivo final de este trabajo: conseguir obtener el nivel de llenado que contiene el recipiente.




Figure 4.6: Eje de orientación atravesando la región de llenado detectada por Fuzzy C-Means en una imagen torcida

Este propósito, como se ha explicado en 3.5, se consigue gracias a unos contadores que recorren los ejes de orientación trazados. Con sus distancias, la distancia real conocida del recipiente y la fórmula recogida en 3.1, se consigue finalmente el nivel de llenado del recipiente translúcido de estructura conocida.

Como se ha comentado al comienzo de este capítulo, las pruebas se han llevado a cabo

con seis niveles de llenado diferente para comprobar que el trabajo es efectivo con volúmenes de líquido de diferentes alturas. A su vez se realizan diez pruebas dentro de cada nivel, correspondientes a imágenes con el recipiente bien orientado, ladeado, a una distancia más cercana, más lejana, etc.

En la figura 4.7 quedan recogidos todos los niveles de llenado resultantes a lo largo de los seis niveles estudiados.




Figure 4.7: Gráfica de los resultados de los diferentes niveles de llenado

Las líneas discontinuas simulan el nivel de llenado real del recipiente, y cada punto corresponde a cada nivel de llenado resultante de cada imagen después de aplicar los algoritmos definidos durante todo el proyecto. Se puede observar que los resultados no son exactos, pero son bastante efectivos y ajustados ya que cuentan con un margen de error de sólo  $\pm 5\text{ml}$ . No se percibe mucha desigualdad entre los resultados de los niveles más bajos respecto a los más elevados, por lo que se puede afirmar que el procedimiento tiene la misma efectividad con niveles dispares.

Tabla 4.1: Datos recogidos de los niveles de llenado

| Niveles de llenado | Resultados de los casos de prueba por cada nivel |     |     |     |     |     |     |     |     |     |
|--------------------|--|-----|-----|-----|-----|-----|-----|-----|-----|-----|
| <b>90ml</b>        | 90   | 85  | 94  | 90  | 89  | 94  | 87  | 86  | 90  | 86  |
| <b>145ml</b>       | 140  | 146 | 141 | 142 | 151 | 141 | 148 | 149 | 146 | 143 |
| <b>185ml</b>       | 180  | 179 | 190 | 188 | 181 | 186 | 182 | 188 | 185 | 190 |
| <b>210ml</b>       | 209  | 214 | 214 | 212 | 214 | 210 | 206 | 208 | 211 | 213 |
| <b>255ml</b>       | 260  | 256 | 261 | 250 | 257 | 259 | 250 | 250 | 255 | 253 |
| <b>310ml</b>       | 304  | 311 | 314 | 315 | 305 | 309 | 308 | 313 | 309 | 305 |

En la tabla 4.1 se recogen todos los valores individuales de todas las imágenes de cada uno de los niveles de llenado.

Todas las imágenes que se han incluido en el estudio, y que quedan reflejadas en la figura 4.7 y en la tabla 4.1, están tomadas de frente, es decir, sin ninguna inclinación. Se ha comentado que el algoritmo es efectivo aún cuando el eje de orientación está ladeado o girado. Sin embargo, no tiene la misma eficacia cuando el ángulo desde el que se toma la fotografía cambia, como es el caso del ejemplo reflejado en la figura 4.8.



Figure 4.8: Imagen tomada con distinta inclinación de ángulo

Los resultados óptimos son los que se han asociado con imágenes donde el recipiente se ha enfocado de frente. Con lo que las imágenes obtenidas desde un ángulo más elevado o más bajo en su defecto, ofrecen resultados muy ineficientes, dónde aplicar los algoritmos explicados en el proyecto carece de utilidad. Se quiso poner solución a este problema mediante la aplicación de homografías, sin embargo, como queda explicado en 3.5 no fue posible. En la figura 4.9 se muestran cuatro casos: en los dos picos superiores el ángulo de la fotografía se toma desde abajo, y en los dos inferiores desde arriba. Es indudable que no aportan resultados favorables, ya que en el peor de los casos el error es de casi 100ml. Esto se debe a que las proporciones del bote, así como sus características cambian lo suficiente como para alterar la efectividad de los algoritmos y por tanto, de los resultados.




Figure 4.9: Gráfica casos de estudio fallidos debido al ángulo de la imagen



## 4.4. Conclusión

En este capítulo se han mostrado finalmente los resultados correspondientes a todas las técnicas que se han ido presentando a lo largo del trabajo. Se ha ido explicando paso por paso todos los procedimientos realizados a través de las referencias visuales ofrecidas por las imágenes. Una vez que se han mostrado los resultados parciales de cada paso se visualizan tanto en una gráfica como en una tabla todos los resultados obtenidos al aplicar los algoritmos pertinentes sobre todo el dataset de imágenes. En general, aunque pueden ser mejorables, se alcanzan unos resultados favorables que han conseguido alcanzar el objetivo principal a pesar de la existencia de determinadas inexactitudes.



## Capítulo 5

# Conclusiones y trabajo futuro

### 5.1. Conclusiones

La finalidad de este trabajo desde un principio ha sido la creación de un desarrollo que fuera capaz de conseguir detectar el nivel de llenado de un recipiente. Para ello, se han atacado varias vías de estudio a lo largo del proyecto para alcanzar este objetivo.

Se ha estudiado el recipiente, que, al ser conocido, ha permitido que se pudieran utilizar sus propiedades favorablemente durante muchos de los desarrollos. Gracias a conocer su forma, y los colores de alguna de sus zonas representativas se ha podido llegar a la obtención por aproximación de una máscara que ha servido como base del estudio. Se han podido aplicar de esta manera algoritmos basados en contornos activos o relacionados con entornos de color.

Al contar con una máscara sobre la que poder continuar, se han investigado y valorado diversas técnicas de segmentación y clustering para conseguir detectar la zona de llenado dentro del recipiente. Se decidió enfocar la atención en los superpíxeles y consecuentemente en técnicas que los utilizan, como es el caso de SLIC y SPDBSCAN. Respecto al clustering se valoraron dos técnicas, siendo elegida finalmente Fuzzy C-Means por ser más flexible y ofrecer mejores resultados. A través de todos estos procedimientos, el área del líquido queda localizada, dando así paso al cálculo del nivel.

En este punto se decidió recorrer la imagen a través de un eje de orientación, el cual detecta además si la imagen está o no torcida. Recorriendo dicho eje se calculó la longitud tanto del recipiente en su totalidad, como la de la zona de llenado. Como ya se ha comentado en diversas ocasiones, el recipiente es conocido, por lo que se sabe su longitud real. Al tener dicha longitud, y las otras dos longitudes previamente citadas de la imagen, se puede calcular el nivel de llenado mediante una relación de linealidad.

En la sección de pruebas y resultados se han podido analizar las distintas muestras a diferentes niveles de llenado. Se ha contado con una base de un número grande de imágenes de muestra, lo que aporta fidelidad a los resultados. A partir de la evaluación de la figura 4.7, que recoge la gráfica con los resultados finales, se sacan conclusiones principalmente positivas, ya que, aunque no son resultados exactos ofrecen aproximaciones bastante relevantes. Las inexactitudes resultantes presentan un margen de error lo suficientemente pequeño como

para poder considerar los resultados como óptimos.

También hay que tener en cuenta el siguiente punto: El hecho de la necesidad de que el fondo de la imagen fuese casi prácticamente ideal para poder crear la aproximación de la máscara, añade por defecto una situación óptima para la detección del llenado como consecuencia. Es decir, en el recipiente, al ser transparente, en la zona de no llenado se observan los detalles del fondo. En este caso no afecta, ya que el fondo tiene tonalidades grises. Sin embargo, esto conduce a tener el siguiente pensamiento crítico: Probablemente, si las imágenes se tomaran con otro tipo de fondos, la detección del nivel de llenado no sería efectiva o como mínimo presentaría mayores niveles de ruido, dificultando así todo el procedimiento.

## 5.2. Trabajo futuro

Aún a pesar de haber sacado conclusiones por lo general positivas de este proyecto, es cierto que se han encontrado puntos bastante mejorables. El principal, desde luego, es la influencia que tiene el grado de inclinación de la fotografía. Como se ha documentado en el capítulo de pruebas 4.3, los resultados asociados con imágenes correspondientes a fotografías que no fueran tomadas de frente, si no desde arriba o desde abajo, han tenido un margen de error elevado. Es decir, no se pueden considerar resultados válidos. Por lo tanto, uno de los trabajos futuros en los que habría que investigar sería en conseguir adaptar dichas inclinaciones para que los algoritmos sean efectivos también con este tipo de imágenes. Si no se consigue esta adaptación, otra opción sería investigar nuevas técnicas que abarquen este tipo de circunstancias.

Por otra parte, siempre se pueden hacer mejoras o innovaciones en los algoritmos y técnicas usadas. Estas mejoras tendrían que ir enfocadas en conseguir mayor robustez frente al ruido que pueda encontrarse en los bordes que se sitúan entre las principales regiones de estudio del recipiente. Se podrían estudiar quizás otro tipo de propiedades del bote u otras versiones de los desarrollos empleados para intentar disminuir el error de detección, ajustando los resultados lo máximo posible al nivel de llenado real.

Finalmente, y como se ha comentado al final de 5.1, un cambio de fondo podría afectar considerablemente a los resultados. Por ello, como trabajo futuro se podría realizar un estudio que investigase los efectos que ocasiona un cambio de fondo. Sería recomendable también plantear nuevas alternativas capaces de solventar la situación en el caso de que los algoritmos de este trabajo no fuesen válidos para dicho suceso.





# Bibliografía

- [1] J. V. Rebaza, “Detección de bordes mediante el algoritmo de canny,” *Escuela Académico Profesional de Informática. Universidad Nacional de Trujillo*, 2007. 4
- [2] J. Ahlberg, “Active contours in three dimensions,” 1996. 4
- [3] L. Fang, T. Qiu, H. Zhao, and F. Lv, “A hybrid active contour model based on global and local information for medical image segmentation,” *Multidimensional Systems and Signal Processing*, vol. 30, no. 2, pp. 689–703, 2019. 4
- [4] C. E. Díaz Torres, “Sistema de control ocular para una silla de ruedas motorizada,” 2019. 5
- [5] A. Vadivel, S. Sural, and A. K. Majumdar, “Human color perception in the hsv space and its application in histogram generation for image retrieval,” in *Color Imaging X: Processing, Hard-copy, and Applications*, vol. 5667, pp. 598–610, International Society for Optics and Photonics, 2005. 5
- [6] J. Mehra and N. Neeru, “A brief review: Super pixel based image segmentation methods,” *Imperial Journal of Interdisciplinary Research*, vol. 2, no. 9, 2016. 5
- [7] R. Achanta, A. Shaji, K. Smith, A. Lucchi, P. Fua, and S. Süssstrunk, “Slic superpixels compared to state-of-the-art superpixel methods,” *IEEE transactions on pattern analysis and machine intelligence*, vol. 34, no. 11, pp. 2274–2282, 2012. 6
- [8] R. Achanta, A. Shaji, K. Smith, A. Lucchi, P. Fua, and S. Süssstrunk, “Slic superpixels,” tech. rep., 2010. 7
- [9] S. Chaudhary and P. B. Nagpal, “Contrivancing dbscan algorithm on spatial data using matlab,” 7
- [10] P. Kovesi, “Image segmentation using slic superpixels and dbscan clustering,” *University of Western Australia, Center for Exploration Targeting, Image Analysis Group*, 2013. 7, 12
- [11] H. Moore, *MATLAB for Engineers*. Pearson, 2017. 8
- [12] Z. Cebeci and F. Yildiz, “Comparison of k-means and fuzzy c-means algorithms on different cluster structures,” *AGRÁRINFORMATIKA/JOURNAL OF AGRICULTURAL INFORMATICS*, vol. 6, no. 3, pp. 13–23, 2015. 13
- [13] J. Nayak, B. Naik, and H. Behera, “Fuzzy c-means (fcm) clustering algorithm: a decade review from 2000 to 2014,” in *Computational intelligence in data mining-volume 2*, pp. 133–149, Springer, 2015. 14
- [14] T. Morris, “Image processing with matlab,” *Supporting Material for COMP27112*, 2016. 14